

A Study on Detection and Classification of Electrotechnical Symbols in Electrotechnical Diagrams using Deep Learning

딥러닝을 이용한 전기 도면의 전기소자 검출 및 분류 연구

Geun-Hyung Kim¹

김근형¹

¹ Professor, Department of Game Engineering, Dong-eui University, Korea, geunkim@deu.ac.kr

Abstract: As the fourth industrial revolution, based on artificial intelligence and data, is actively taking place in various industrial domains, digital transformation is also happening rapidly. Even before the advent of the digital economy, companies accumulated and utilized analog data. With the emergence of machine learning technologies using data, the value of data is increasing, so it is crucial to transform analog data into data that computers can understand to increase the utilization of existing analog data. In order to utilize paper-based diagrams in a computer, electrotechnical symbols, lines, and text on the paper-based diagrams must be detected. In this paper, we discuss the technology required to convert paper-based diagrams into digital data so that they can detect electrotechnical symbols and the electrotechnical symbol recognition method using deep learning technology. Specifically, we divide the step of converting paper-based diagrams to digital diagrams into three procedural steps: electrotechnical device detection, line detection, and text detection. In addition, we propose an electrotechnical device detection method based on the Faster R-CNN neural network. We use the actual and test diagrams synthesized with representative electrotechnical devices of the IEC 60617 standard. We confirm that the proposed method has higher precision and recall than the Fast R-CNN-based electrotechnical device detection.

Keywords: Object Detection, Electrotechnical Symbol Detection, Electrotechnical Diagrams, Deep Learning

요약: 여러 산업영역에서 인공지능과 데이터를 활용한 4차 산업혁명이 활발하게 이루어지면서 아날로그 데이터의 디지털 전환이 빠르게 이루어지고 있다. 그러나 디지털 경제가 도래하기 전에도 기업들은 아날로그 형태의 데이터를 축적하고 활용하였다. 데이터를 활용한 기계학습 기술의 등장으로 데이터의 가치가 증가하고 있어 기존의 아날로그 데이터의 활용도를 높이기 위해 아날로그 데이터를 컴퓨터가 이해할 수 있는 디지털 데이터로 변환하는 것이 매우 중요하다. 종이 도면을 컴퓨터에서 활용하기 위해서 종이 도면의 전기소자, 회선, 텍스트를 검출하여야 한다. 본 논문에서는 종이 도면에서 전기소자를 검출하여 디지털 데이터로 변환하는 데 필요한 기술과 딥러닝 기술을 활용한 전기소자 인식 방법에 대해 논의한다. 구체적으로 우리는 종이 도면을 디지털 도면으로 전환하는 단계를 전기소자 검출, 회선 검출, 텍스트 검출의 세 개의 절차적인 단계로 나눈다. 또한 Faster R-CNN 신경망에 기반을 둔

Received: February 03, 2023; 1st Review Result: March 18, 2023; 2nd Review Result: April 17, 2023
Accepted: May 31, 2023

전기소자 검출 방법을 제안한다. IEC 60617 표준의 대표적인 전기소자로 구성된 실제 도면과 테스트 도면을 사용하였으며 제안한 방법이 Fast R-CNN 기반 전기소자 검출 방법보다 정밀도와 재현율이 높음을 확인했다.

핵심어: 객체인식, 전기소자 검출, 전기 도면, 딥러닝

1. 서론

전기 도면은 많은 전기소자와 전기소자 간 연결을 표현하는 회선, 전기소자 및 회선에 대한 부가 설명을 위한 텍스트로 구성된 회로도이다. 자동차, 선박을 제작하기 전에 설계도를 작성하듯이 전기 시스템을 제작하기 위해 회로도를 작성하고 있다. 1963년 자동차 제조사 GM과 IBM이 개발한 그래픽 기반 CAD(Computer Aided Design) 프로그램인 DAC-1(Design Augmented by Computer)가 출시된 이후 현재까지 수많은 상용 CAD 프로그램이 활용되고 있다. CAD 프로그램을 활용하여 설계된 회로도는 디지털 데이터 형태로 저장되어 있어 비슷한 기능을 갖는 전기 시스템을 제작할 때 많은 부분 재사용이 가능하여 설계 시간을 단축할 수 있으며 회로의 동작을 분석할 수 있는 시뮬레이션 소프트웨어를 사용하여 실제 제작을 하지 않고도 설계된 회로를 검증할 수 있다.

그러나 CAD 프로그램을 이용하여 설계된 회로도가 종이 형태로만 존재하거나 손으로 직접 작성되어 종이 도면만 존재하는 경우가 많다. 회로도의 데이터는 유용한 정보를 포함하고 있으나 종이 도면의 회로도는 활용하는데 제한이 있다. 종이 도면이 가진 유용한 정보를 컴퓨터에서 활용하기 위해서는 종이 도면의 디지털 전환이 필요하다. 일반적으로 종이 도면을 디지털 도면으로 전환하기 위해서 개발자가 직접 종이 도면의 회로도와 동일하게 CAD 프로그램을 이용하여 다시 작성하는데 이 방법은 많은 시간이 소요되고 작성 중 사람의 실수가 존재할 가능성이 있어 효율적인 방법이 요구된다.

본 연구의 목표는 종이 도면을 스캔 한 이미지 데이터로부터 전기소자를 인식하는 방법을 연구하는 것이다. 물론 전기 도면을 구성하는 관련 텍스트뿐만 아니라 전기소자 간의 연결을 감지하는 것도 중요하나 다른 알고리즘을 적용하여야 하기 때문에 본 연구에서는 종이 도면에서 전기소자를 검출하고 분류하는 방법을 다룬다. 본 논문에서는 종이 도면에서 전기소자를 검출하기 위해서 컴퓨터 비전 기술을 활용한 기존 연구[1]와 달리 딥러닝 모델인 Faster R-CNN(Regions with Convolutional Neuron Network features)[2]을 적용하여 얻은 내용을 기술한다.

종이 도면 내 전기소자의 검출 및 분류를 위해 기계학습 또는 딥러닝 기반 방법이 사용되고 있으며 최근 딥러닝 분야의 발전으로 종이 도면에서 객체를 검출하기 위해 딥러닝을 활용한 연구가 많이 진행되고 있다. 2020년 초부터 손으로 직접 그린 회로도에서 소자 검출을 위해 딥러닝 기술이 적용되었다. Wang은 손으로 직접 작성한 세 가지 전자소자를 인식하기 위해 딥러닝 기반의 컨볼루션 신경망(CNN: Convolutional Neuron Network)을 통해 추출한 특징에 대해 소프트맥스(Softmax) 분류기를 이용하여 객체를 분류하며 모델을 학습시켰다[3]. 손으로 직접 작성한 다이오드, 저항, 콘덴서를 분류하는 연구에 사용된 CNN은 회로도 내의 소자뿐만 아니라 일반적으로 이미지에서 객체 검출 및 영상처리에 사용되고 있다[4]. 최근 실시간 객체 인식 방법으로 Faster R-CNN 방법보다 인식 속도가 빠른 YOLO(You Only Look Once) 방법[5]이 제안되었으며 전기 도면에서 전기소자 검출에 활용되고 있다[6]. 본 논문은 종이 도면의 디지털 전환 시

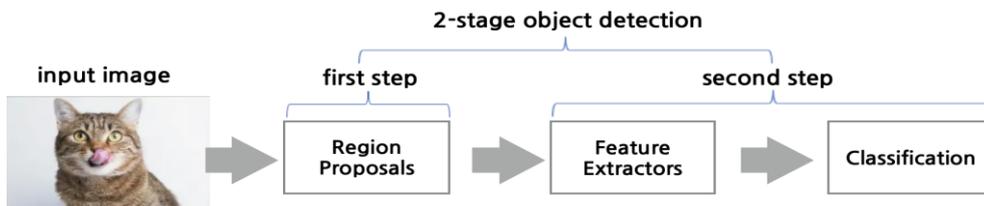
회로도의 전기소자의 검출 속도보다는 검출 정확도를 우선 고려하여 Faster R-CNN 방법에 기반한다.

논문의 구성은 다음과 같다. 2장에서 R-CNN 계열의 딥러닝 기반 객체 인식 방법과 회로도에서 소자를 검출하는 기존 연구를 소개한다. 3장에서는 종이 도면의 디지털 전환을 위해 제안한 방법을 설명한다. 4장에서는 실험 환경과 실험 결과를 제시하고 분석한 후 마지막으로 5장에서 결론과 향후 계획을 제시한다.

2. 관련 연구

2.1 딥러닝 기반 객체 인식 프레임워크

딥러닝 기반 객체 인식 프레임워크는 1단계(1-stage) 객체인식 방법과 2단계(2-stage) 객체인식 방법으로 분류한다. 2단계 객체인식 방법은 [그림 1]과 같이 먼저 영역 제안 생성기를 사용하여 객체가 있을 것 같은 영역을 도출하고 각 도출된 영역에 대해 특성을 추출(1단계) 한 후 제안된 영역의 범주를 예측하는 영역 분류기(2단계)를 사용하여 객체를 인식한다[7].



[그림 1] 2단계 객체인식 메커니즘

[Fig. 1] 2-Stage Object Detection Mechanism

1단계 검출 방법은 [그림 2]와 같이 영역 분류 단계 없이 특성 맵(feature map)의 각 위치에서 인식 대상 객체의 범주에 대해 객체의 인식을 직접 수행한다.



[그림 2] 1단계 객체인식 메커니즘

[Fig. 2] 1-Stage Object Detection Mechanism

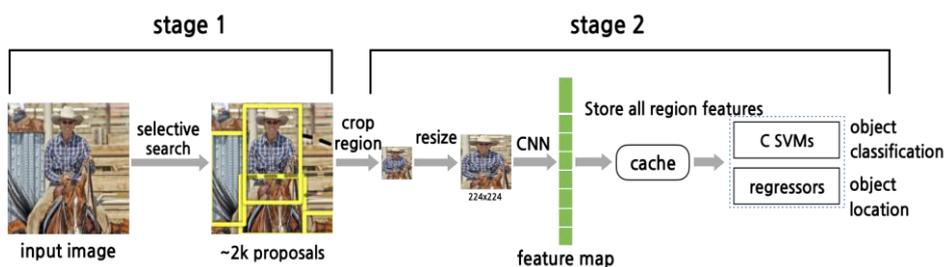
2단계 검출 방법의 예로는 R-CNN, Fast R-CNN, Faster R-CNN 등이 있으며 1단계 검출 방법의 예로는 YOLO, SSD(Single Shot Detectors) 등이 있다. 객체인식의 정확도 측면에서는 2단계 검출 방법이 1단계 검출 방법보다 높으며 인식 속도 측면에서는 1단계 검출 방법이 2단계 검출 방법보다 빠르다.

2.2 컨볼루션 신경망(CNN: Convolution Neural Network)

컨볼루션 신경망은 이미지와 비디오에서 특징을 찾아내는 딥러닝 네트워크로 2010년 이후 커다란 발전이 이루어져서 현재 널리 사용되고 있다. 컨볼루션 신경망은 일반적으로 컨볼루션 계층, ReLU(Rectified Linear Unit) 계층, 최댓값 풀링(Max Pooling) 계층, 평탄화(Flatten) 계층으로 구성된다. 컨볼루션 계층은 컨볼루션 신경망의 핵심으로 이미지 내 영역 별 특징을 추출하기 위해 해당 영역의 이미지 픽셀에 필터의 가중치를 곱한 결과의 합을 구한다. 필터의 가중치는 학습 단계에서 적절한 값으로 갱신되어 이미지의 영역을 특징짓는 특성 맵을 도출한다. 컨볼루션 신경망에서는 여러 개의 필터를 사용하며 특성 맵은 각 필터의 가중치에 따라 형태가 결정된다. 컨볼루션 계층의 결과는 ReLU 활성화함수(activation function)을 통해 음수 값을 0으로 변환한다. ReLU 활성화함수의 출력은 최댓값 풀링 계층을 통해 전체 데이터 중 중요 데이터만을 추출하여 고려할 데이터양을 줄인다. 평탄화 계층은 신경망의 데이터를 일차원 데이터로 변환한 후 필요한 기능을 제공하는 신경망에 연결하는데 사용된다.

2.3 R-CNN, Fast R-CNN and Faster R-CNN

R-CNN(Regions with CNNs features)[6] 계열의 신경망은 특정 영역에 대해서 컨볼루션 신경망의 특성 맵을 추출하여 객체인식을 하는 신경망이다. 먼저 입력 이미지에 대해 선택적 탐색(selective search)를 진행하여 객체가 존재할 것이라 여겨지는 영역(ROI: Region of Interest)을 약 2,000개 정도 추출한다. 추출된 ROI는 각각 크기와 위치가 달라 동일한 크기의 정사각형으로 만든다. 각 ROI는 컨볼루션 신경망을 이용하여 특성 맵을 추출하여 추출된 특성 맵에 대해 SVM(Support Vector Machine) 분류기를 적용하여 ROI의 객체가 어떤 클래스에 해당하는지 분류(object classification) 한 후 컨볼루션 신경망을 통해 얻은 바운딩 박스(bounding box)의 위치를 상세 조정하기 위해 박스 회귀분석기(box regressor)를 이용하여 객체의 정확한 위치(object location)를 예측한다. 그림 3은 R-CNN 객체인식 모델의 절차를 보인다.



[그림 3] R-CNN 객체인식 모델

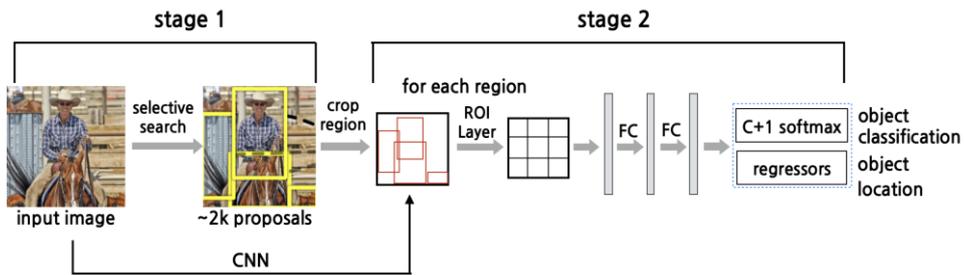
[Fig. 3] R-CNN Object Recognition Model

R-CNN 객체인식 모델은 선택적 탐색 결과가 고정되어 있으며 SVM과 박스 회귀분석기의 예측 오류가 컨볼루션 신경망의 필터 가중치 조정에 반영되지 않아 전체 네트워크 차원에서 학습이 이루어지지 않는다.

Fast R-CNN[8]은 이미지에서 ROI를 추출한 후 각 ROI에 대해서 컨볼루션 신경망을 적용하는 R-CNN과 달리 ROI 추출과 컨볼루션 신경망 적용 순서를 변경하여 먼저

이미지에 컨볼루션 신경망을 적용하여 특성 맵을 추출한다. 그 후 전체 이미지의 특성 맵에서 선택적 탐색으로 추출한 ROI를 식별하고 사각형을 변형하고 ROI 풀링을 통해 데이터를 고정 크기로 재구성한 후 FC(fully connected) 네트워크를 적용한다. Fast R-CNN은 소프트맥스(Softmax) 분류기와 바운딩 박스 회귀분석기를 이용하여 객체 분류와 객체의 바운딩 박스를 예측한다. 네트워크 차원에서 학습이 이루어지지 않는다.

Fast R-CNN은 영역 추천 방법을 수행하기 전에 컨볼루션 연산 결과를 공유하기 때문에 학습 시간과 예측 시간이 줄었으며 클래스 분류기와 박스 회귀분석기의 오차가 컨볼루션 신경망의 가중치에 반영되어 전체 네트워크에서 학습이 이루어진다. 그림 4는 Fast R-CNN 객체 인식 모델의 절차를 보인다.

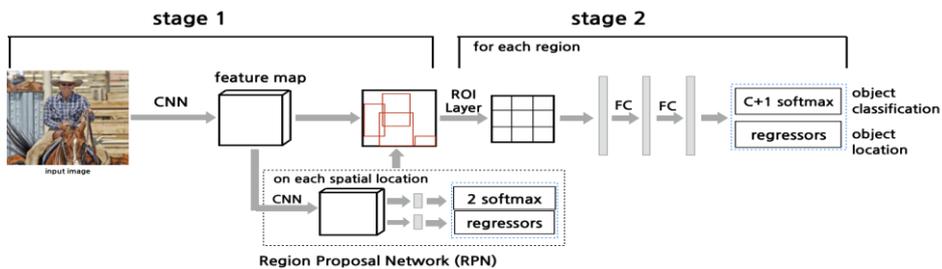


[그림 4] Fast R-CNN 객체인식 모델

[Fig. 4] Fast R-CNN Object Recognition Model

Faster R-CNN은 ROI를 추출하기 위해 R-CNN과 Fast R-CNN의 선택적 탐색과 달리 RPN(region proposal network)을 제안한다. 전체 이미지에 대해 컨볼루션 신경망을 적용하여 추출한 특성 맵에 신경망을 적용하여 객체가 있을만한 영역을 예측하여 R-CNN과 Fast R-CNN보다 ROI 추출 시간을 줄인다. 또한 RPN에서 위치를 정확하게 예측할 수 있도록 k 개의 서로 다른 앵커 박스(anchor box)에 정의하고 각 앵커 박스에 대해서 특성 맵을 추출하고 분류와 회귀분석을 수행한다. RPN은 단순히 객체가 있을 만한 위치를 제안하는 것으로 객체가 있는지 없는지에 대해서만 알려준다.

Faster R-CNN은 학습이 이루어진 후 GPU 상에서 한 번의 포워딩을 수행하면 객체를 인식하고 위치를 예측할 수 있어 빠르게 동작한다. 그 외에는 Fast R-CNN에서 사용한 네트워크 구조를 그대로 적용하여 각 객체의 인식과 위치를 찾는다. Faster R-CNN은 Fast R-CNN의 선택적 탐색 기능을 RPN으로 대체하고 중단 간 형태로 학습을 수행한다.



[그림 5] Faster R-CNN 객체인식 모델

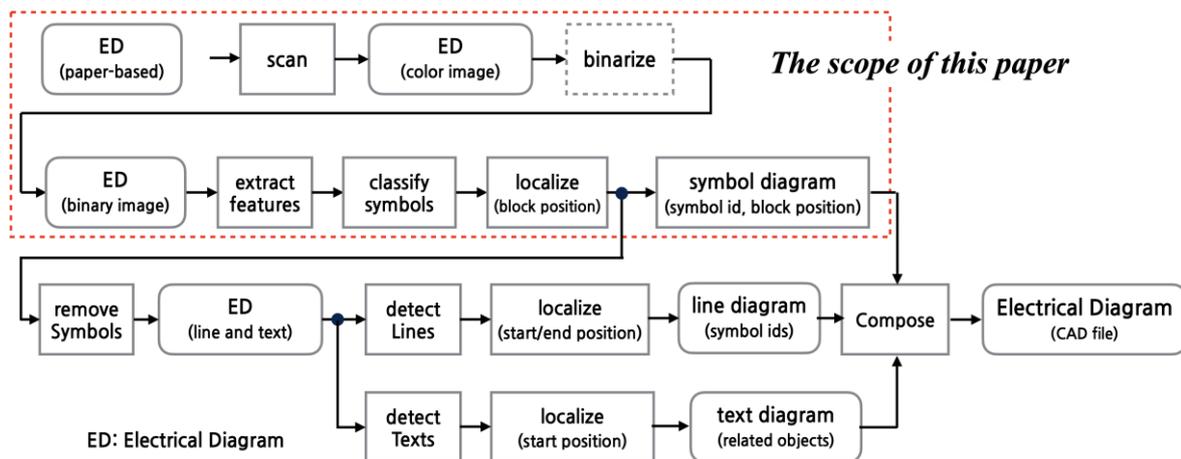
[Fig. 5] Faster R-CNN Object Recognition Model

3. 제안한 방법

3.1 전기 도면의 디지털 전환

종이에 작성된 전기 도면의 디지털 전환은 종이 도면을 스캔하여 이미지 파일로 전환하는 방법과 개발자가 종이 도면을 CAD 프로그램을 사용하여 CAD 파일로 전환하는 방법이 있다. CAD 파일로 저장된 전기 도면은 향후 물리 시스템의 변경 내용을 지속적인 유지 보수가 가능하고 회로도의 회로를 직접 구현하지 않고도 시뮬레이션을 통해 회로를 검증할 수 있다.

본 논문에서는 딥러닝 기반 Faster R-CNN 모델을 활용하여 종이 도면을 CAD 파일의 형태로 디지털 전환을 하는 과정에서 전기 도면을 구성하는 전기소자(심벌)의 종류와 위치를 검출한다. 종이 전기 도면을 CAD 파일 형태로 전환하는 전체 절차는 [그림 6]과 같다. 디지털 이미지 파일로 구성된 전기 도면에서 전기소자에 해당하는 심벌을 검출한 후 심벌을 제안한 전기 도면에서 심벌 간 연결을 표현하는 회선의 검출과 전기소자 및 연결에 대한 설명을 기술한 텍스트를 검출한 후 세 가지의 검출 결과 정보를 조합하여 최종적으로 CAD 파일을 구성하게 된다. 본 논문의 내용은 그림 1의 점선 박스로 표시한 전기소자(심벌) 검출에 관한 것이다.



[그림 6] 종이 기반 전기 도면의 디지털 전환 흐름도

[Fig. 6] Digital Transformation Flow of Paper-based Electrotechnical Diagrams

3.2 제안한 딥러닝 방법

종이 도면의 CAD 파일로 전환은 [그림 6]과 같은 디지털 전환 흐름도에 표현한 순서에 따라 진행되며 본 논문에서 제안하는 전기소자 검출 방법에는 딥러닝 기반 객체인식 방법인 Faster R-CNN 방법을 적용한다. Faster R-CNN은 RPN 부분과 Fast R-CNN 부분으로 구분할 수 있다. RPN 부분과 Fast R-CNN 부분은 특성 맵을 도출하는 데 사용한 컨볼루션 네트워크를 공유하지만 학습에 필요한 모델, 손실 함수, 학습 방식이 다르다. 먼저 고정된 크기의 윈도우를 이미지에서 슬라이딩하며 객체를 검출하는 기존의 방법에 비교하여 제안한 방법은 Faster R-CNN 방법과 같이 3가지의 스케일과 3가지의 가로와

세로 비율로 구성된 9개의 앵커 박스에서 객체를 검출한다. 컨볼루션 네트워크에서 얻은 특성 맵($W \times H$)에 대해 앵커 박스가 총 $W \times H \times k$ 개 존재한다. 본 논문에서는 특성 맵을 도출하는 데 사용되는 컨볼루션 네트워크로는 Inception-Resnet-v2 신경망을 사용하였다.

RPN은 Inception-Resnet 신경망을 통해 얻은 특성 맵 데이터에 제로 패딩 한 후 3x3 컨볼루션 연산을 수행하여 특성 맵과 같은 크기의 중간 특성 맵(intermediate feature map)을 구한다. 중간 특성 맵에 대해서 객체의 존재와 객체 위치를 각각 예측하기 위해 앵커 박스 별로 1x1 컨볼루션 연산을 수행한다. 각 앵커 박스에 대해서 객체의 존재 유무를 예측한 결과와 바운딩 박스의 네 좌표 점을 회귀분석한 결과를 얻는다.

RPN을 학습시킬 때 사용되는 손실 함수는 식 (1)과 같다. 손실 함수는 객체 검출에 따른 손실(L_{cls})과 바운딩 박스 회귀분석에 따른 손실(L_{reg})을 더한 것이다. 식(1)에서 i 는 앵커 박스의 인덱스이고 p_i 는 해당 앵커 박스에 객체가 있을 확률, t_i 는 바운딩 박스 회귀분석을 통해 얻은 앵커 박스의 조정 벡터를 의미한다. p_i^* 와 t_i^* 는 검증용 실제 정보(ground truth)에 대해 객체가 존재할 확률과 검증용 실제 정보에 대한 조정 벡터를 뜻한다. λ 는 밸런스 파라미터로 N_{cls} 와 N_{reg} 차이에 대한 균형을 맞추기 위해 사용된다. 학습을 위해 사용되는 미니 배치(mini-batch)의 크기(N_{cls})는 256개이고 이미지 내에서 사용된 모든 앵커 박스의 위치의 수(N_{reg})는 약 2,400개인 경우 λ 의 기본 값은 10으로 설정한다. L_{cls} 는 크로스 엔트로피 손실, L_{reg} 는 $smooth_{L1}$ 을 이용한다.

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \quad (1)$$

식(1)의 첫째항은 객체 검출에 대한 손실 항이고 둘째 항은 회귀분석 손실 항으로 배경에서는 회귀분석 손실을 반영하지 않는 것으로 객체가 존재하지 않는 경우에는 학습에서 제외한다. 식 (1)의 손실 함수와 미니 배치를 역전파하고 확률적 경사하강법(SGD: Stochastic Gradient Descent)을 이용하여 RPN을 학습시킨다.

RPN에 의해 객체가 존재할 것으로 예측된 ROI는 Fast R-CNN 모듈을 통해 객체 분류와 위치를 예측하는 객체 인식을 수행한다. Fast R-CNN 모듈에서 RPN의 모든 앵커블록을 ROI로 고려하지 않고 비최대값 억제(non-maximum suppression)를 적용하여 확률이 높은 앵커블록만을 ROI로 고려한다. RPN과 Fast R-CNN 모듈을 이용하여 객체를 인식하기 위해서 본 논문에서는 RPN을 먼저 학습한 후 RPN의 ROI를 이용하여 Fast R-CNN 모듈과 Resnet-v2 신경망을 학습한다. 학습된 Resnet-v2 신경망을 통해 특성 맵을 다시 도출하고 RPN을 학습한다.

4. 실험 결과

4.1 실험 환경 및 데이터셋

실험에 사용한 전기 도면의 전기소자는 IEC(International Electro-technical Commission) 60617 표준[9] 규격을 따른다. IEC 60617 표준은 전기 도면에 사용하는 약 1,900개의 전기소자에 대한 심벌을 표준하고 있다. 전기 도면을 구성하는 전기소자를 검출하기 위한 실험은 구글 Colab 환경과 Apple M1 칩 셋의 맥북 프로에서 수행하였다. 본 실험에서는 1,900개의 전기소자에서 전력용 차단기(No fuse breaker) 3개, 전력용 차단기/모터 과부하

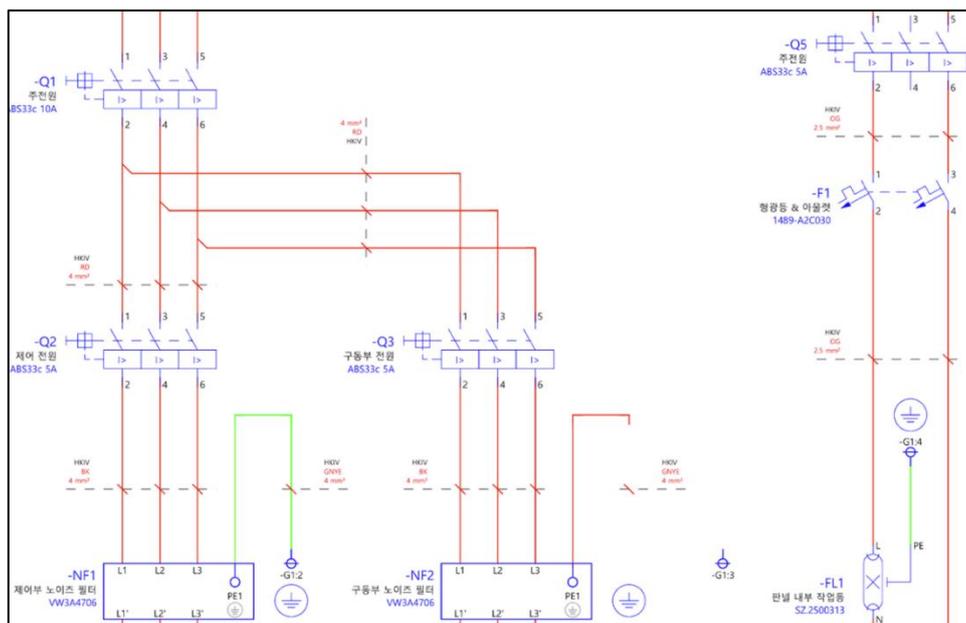
스위치(Molded case circuit breaker) 2개, 전력용 차단기(Electric leakage breaker) 1개, 전력용 차단기와 모양이 유사한 열동형 릴레이의 전자식 장치(Electromechanical device of a thermal relay) 1개, 변압기(Potential Transformer) 5개, 압력 스위치를 포함한 10개의 스위치를 사용하였다.

본 실험에서는 전기 도면을 구성하는 전기소자를 검출 가능성을 검증하기 위해서 대상 전기 도면을 구성하는 대표적인 전기소자를 크기와 유사성을 고려하여 선정하였다. 그리고 선택한 전기소자 중 변압기와 전력용 차단기와 같은 상대적으로 큰 전기소자와 스위치와 같은 작은 전기소자로 분류하여 모델을 학습하였다. [표 1]은 실험에서 검출에 사용한 19개 전기소자 중 상대적으로 큰 전기소자와 작은 전기소자 중 일부를 나타낸다. 전기소자의 19개 전기 소자들은 전기 도면에 사용 빈도가 많은 전기 소자들 중 형태가 유사한 것들을 선택하였다. 변압기와 전력용 차단기의 크기는 약 250x200 픽셀이며 스위치의 크기는 보통 큰 전기소자의 1/4에서 1/2 정도이다

[표 1] 실험에서 사용한 전기소자 예

[Table 1] An Example of Electrotechnical Symbols used in Experiments

큰 전기 소자	과부하스위치		열동형 릴레이	0상 변압기	3상 변압기	
작은 전기 소자	NC 접점	NO 접점	Cam 스위치	압력 스위치	회전식 스위치	3 개폐 스위치



[그림 7] 실험에 사용한 전기 도면 예 (일부)

[Fig. 7] Example of Electrotechnical Diagram used in Experiment

실제 전기 도면의 개수가 학습에 사용하기에 충분하지 않아서 큰 전기소자와 작은 전기소자로 구성된 도면과 실제 전기 도면에서 전기소자를 추출하여 테스트용 전기 도면을 생성하였다. [그림 7]은 실험에서 학습한 모델을 활용하여 사용한 실제 전기 도면의 한 예이다.

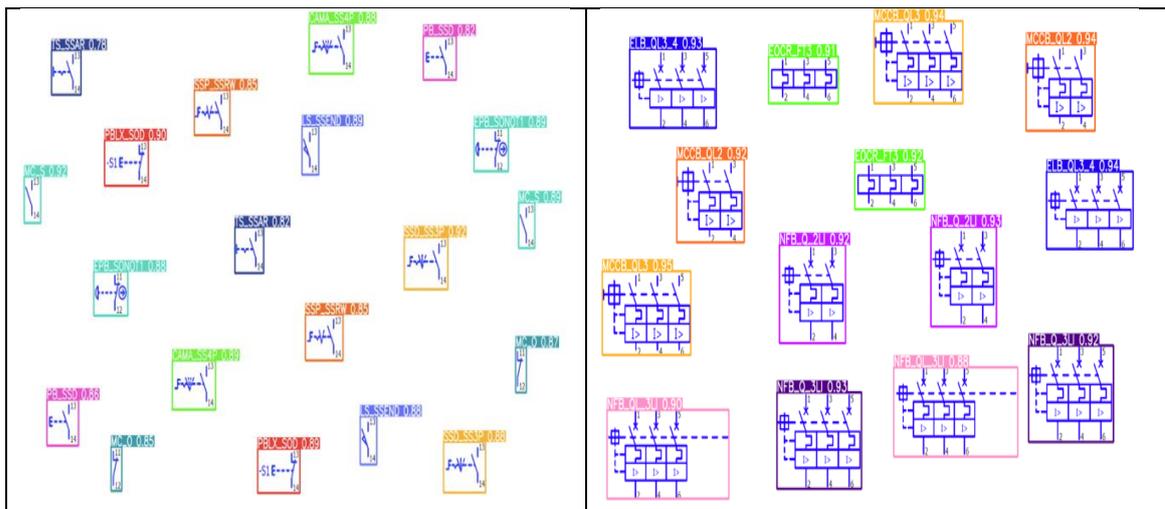
모델을 학습하기 위해서 작은 전기소자와 큰 전기소자로 구성된 전기 도면 80장을 만들었다. 이 중 학습용 도면으로 60장, 검증용 도면으로 12장, 테스트용 도면으로 8장을 구분하여 모델을 학습하였다. 학습한 모델은 검출 대상인 전기소자가 포함된 실제 전기 도면과 테스트를 위해 만든 전기 도면을 대상으로 모델을 성능을 검증하였다.

4.2 실험 결과

Faster R-CNN 신경망에 기반한 제안한 방법을 전기소자만으로 생성한 전기 도면, 실제 전기 도면을 대상으로 실험을 하였다. 제안한 방법의 검출 정확도와 속도를 Fast R-CNN 신경망을 활용한 전기소자 검출 결과와 비교하였다.

4.2.1 생성한 전기 도면에 대한 실험

고려하는 전기소자를 임의로 배치하여 생성한 전기 도면을 활용하여 전기 도면 검출을 실험하였다. 학습, 검증, 검출을 위해 생성한 전기 도면은 2500x1400 픽셀로 구성되며 큰 전기소자와 작은 전기소자로 전기 도면에 대해서 제안한 방법과 Fast R-CNN 신경망의 전기소자 검출 결과를 비교하였다. 전기 도면을 제안한 방법과 Fast R-CNN 신경망의 입력으로 사용하기 위해 1000x1000으로 이미지 자르기(crop)하여 전처리하였다. [표 2]는 제안한 방법과 Fast R-CNN 신경망을 적용하여 얻은 성능 비교 결과이다. 큰 전기소자로 구성된 전기 도면의 경우 [표 1]의 3상 변압기가 검출되지 않는 전기 도면이 존재하였다. 작은 전기소자로 구성된 전기 도면의 경우 [표 1]의 Cam 스위치, 압력 스위치, 3개폐 스위치의 검출이 되지 않거나 잘못 검출되는 전기 도면과 NC 접점, NO 접점의 검출이 잘못되는 전기 도면이 존재하였다.



[그림 8] 전기소자 검출 결과 예 (좌: 작은 전기소자, 우: 큰 전기소자)

[Fig. 8] An Example of Detection of Electrotechnical Devices (left: small device, right: large device)

제안한 방법은 큰 전기소자로 구성된 전기 도면에서는 정밀도가 99.2%, 재현율은 97.4%, mAP는 98.7%로 작은 전기소자로 구성된 전기 도면에서는 정밀도가 86.1%, 재현율은 84.2%, mAP는 85.6%이었다. 제안한 방법은 Fast R-CNN보다 정밀도가 약 4%p, 재현율은 약 3%p, mAP은 약 3%p 정도 좋은 성능을 보인다.

[표 2] 제안한 방법과 Fast R-CNN 성능 비교 (생성 전기 도면)

[Table 2] Performance Comparision of the Proposed Method and Fast R-CNN (Synthetic Electrotechnical Diagram)

모델	작은 전기소자 (%)			큰 전기소자 (%)		
	Precision	Recall	mAP	Precision	Recall	mAP
제안한 방법	86.1	84.2	85.6	99.2	97.4	98.7
Fast R-CNN	82.5	81.6	82.1	98.5	94.3	95.7

[그림 8]의 왼쪽은 작은 전기소자로 생성한 테스트 전기 도면에서 전기소자를 검출한 결과 중 한 예이고 오른쪽은 큰 전기소자로 생성한 테스트 전기 도면에서 전기소자 검출이 제대로 이루어진 결과 예이다.

4.2.2 실제 전기 도면에 대한 실험

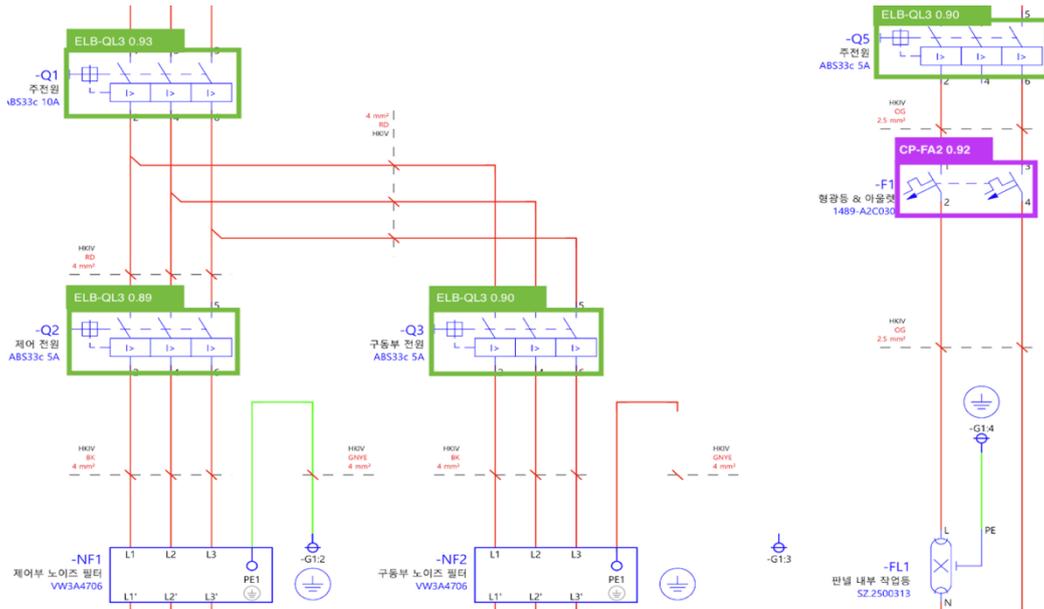
전기소자로 생성한 전기 도면을 통해 학습한 모델을 이용하여 산업 현장에서 작성된 실제 전기 도면을 대상으로 전기소자 검출 실험을 수행하였다. 실제 전기 도면은 전기소자만으로 생성한 전기 도면과 다르게 전기소자, 회선 및 텍스트로 구성되어 있다. 실제 전기 도면에 대해 제안한 방법과 Fast R-CNN 신경망을 적용시켜 전기소자 검출 성능은 다음 [표 3]과 같다. 제안한 방법의 정밀도(precision)는 92.3%, 재현율(recall)은 88.2%, mAP는 89.7%이고 Fast R-CNN 신경망의 정밀도는 85.5%, 재현율은 80.4%, mAP는 84.9%이다. 실제 전기 도면은 전기소자의 검출 정확도가 전기소자만으로 구성된 전기 도면에서 전기소자의 검출 정확도보다 낮은 성능을 보이는데 이는 회선과 텍스트의 영향에 의한 것으로 분석된다.

[표 3] 제안한 방법과 Fast R-CNN 성능 비교 (실제 전기 도면)

[Table 3] Performance Comparision of the Proposed Method and Fast R-CNN (Real Diagram)

모델	실제 전기 도면 (%)		
	정밀도(Precision)	재현율(Recall)	mAP
제안한 방법	92.3	88.2	89.7
Fast R-CNN	85.5	80.4	84.9

[그림 9]는 [그림 7]의 실제 전기 도면에 대해서 전기소자의 검출 결과이다. [그림 7]의 전기 도면은 2 종의 큰 전기소자로 구성된다.



[그림 9] 실제 전기 도면의 전기소자 검출 결과 예

[Fig. 9] An Example of the Detection of Electrotechnical Devices in an Actual Diagram

5. 결론

본 논문에서는 종이 기반 전기 도면을 컴퓨터에서 활용할 수 있도록 디지털 전환하기 위해 전기 도면의 구성 요소를 전기소자, 회선, 텍스트로 구분하고 전기 도면에서 전기소자 검출, 회선 검출, 텍스트 검출의 세 개의 절차적인 단계로 구성된 디지털 전환 흐름도를 제시하고 첫 단계인 전기 도면에서 전기소자 검출을 위해 Faster R-CNN 신경망을 이용한 전기소자 검출 방법을 제안하고 실험을 수행하였다. 실험을 위한 전기도면은 IEC 60617 표준의 대표적인 전기소자에서 상대적으로 크기가 큰 소자와 작은 소자로 구분하여 만든 전기 도면과 실제 도면을 이용하여 학습하고 학습된 전기소자의 검출을 확인하였다. 본 논문에서는 제안한 방법과 Fast R-CNN 기반 전기소자 검출 방법의 성능을 정밀도, 재현율, mAP 를 이용하여 비교하였다. Faster R-CNN 기반의 전기소자 검출 방법의 정밀도가 Fast R-CNN 방법보다 생성한 전기 도면에서는 약 4%p 정도 실제 전기 도면에서는 약 7%p 정도 높게 나타났다. 본 논문에서 IEC 60617 표준 심벌의 일부로 구성된 전기 도면에서 전기소자 검출에 Faster R-CNN 신경망을 활용 가능성을 확인하였으며 Fast R-CNN 신경망의 검출 결과와 비교를 하였다. 앞으로 다양한 전기 소자로 구성된 전기 도면과 실제 도면에 대해서 딥러닝 기술을 적용하여 전기소자 검출 실험을 하고 회선과 텍스트 검출도 수행하여 종이 기반 전기 도면을 디지털 전기 도면으로 전환할 계획이다.

6. 감사의 글

이 논문은 2022학년도 동의대학교 교내연구비에 의해 연구되었음(202201790001)

References

- [1] S. V. Blameyko, S. Uchida, Recognition of Engineering Drawing Entities: Review of Approaches, International Journal of Image and Graphics, (2007), Vol.7, No.4, pp.703-733.
DOI: <https://doi.org/10.1142/S0219467807002878>
- [2] S. Ren, K. He, R. Girshick, and J. Sun, Faster R-CNN: Toward Real-Time Object Detection with Region Proposal Networks, (2016),
DOI: <https://doi.org/10.48550/arXiv:1506.01497>
- [3] H. Wang, T. Pan, M. K. Ahsan, Hand-drawn electronic component recognition using deep learning algorithm, International Journal of Computer Applications in Technology, (2020), Vol.62, No.1 pp.13-19.
DOI: <https://doi.org/10.1504/ijcat.2020.103905>
- [4] X. Wu, D. Sahoo, S. C. H. Hoi, Recent Advances in Deep Learning for Object Detection, (2019)
DOI: <https://doi.org/10.48550/arXiv.1908.03673>
- [5] J. Redmon, S. Divvala, R. Girshick, A. Farhadi, You Only Look Once: Unified, Real-Time Object Detection, Proceeding of Computer Vision and Pattern Recognition (CVPR), IEEE, (2016),
Available from: <https://pjreddie.com/darknet/yolo>
- [6] J. Si, M. Kim, S. Kim, Converting Close-Looped Electronic Circuit Image with Single I/O Symble into Netlist, Journal of KIIT, (2021), Vol.19, No.8, pp.1-10.
DOI: <https://doi.org/10.14801/jkiit.2021.19.8.1>
- [7] R. Girshick, J. Donahue, T. Darrell, J. Malik, Rich feature hierarchies for accurate object detection and semantic segmentation, (2014)
DOI: <https://doi.org/10.48550/arXiv.1311.2524>
- [8] R. Girshick, Fast R-CNN, (2015)
DOI: <https://doi.org/10.48550/arXiv.1504.08083>
- [9] IEC 61617 database, IEC 61617 – Graphic Symbols for Diagrams, (2022)
Available from: <https://std.iec.ch/iec60617>